

Sprachverarbeitung I / 3    HS 2016

# Kurzzeitanalyse: DFT, Autokorrelation

Buch: Kapitel 4.1–4.4

Beat Pfister



# Sprachverarbeitung I / 3

Vorlesung: Kurzzeitanalyse von Sprachsignalen

- Zweck der Kurzzeitanalyse
- Diskrete Fouriertransformation
- Spektrum periodischer Signale
- Spektrum rauschartiger Signale
- Autokorrelation

Übung: diskrete Fouriertransformation

# Kurzzeitanalyse

## Beispiel: Spektral- oder Fourieranalyse

	Langzeitanalyse (stationäres Signal)	Kurzzeitanalyse (quasi-stationäres Signal)
Analyseabschnitt:	möglichst lang	kurz, nahezu stationär >>>
erwartetes Resultat:	spektrale Zusammensetzung des Signals (ein Vektor)	spektrale Zusammensetzung zu bestimmten Zeitpunkten (Sequenz von Vektoren)
Beispiele:	stationäres Signal >>> Sprachsignal >>>	stationäres Signal >>> Sprachsignal >>> >>>

# Diskrete Fouriertransformation (DFT)

$$X(k) = \sum_{n=0}^{N-1} x(n) e^{-j(2\pi/N)kn} \quad 0 \leq k \leq N-1$$

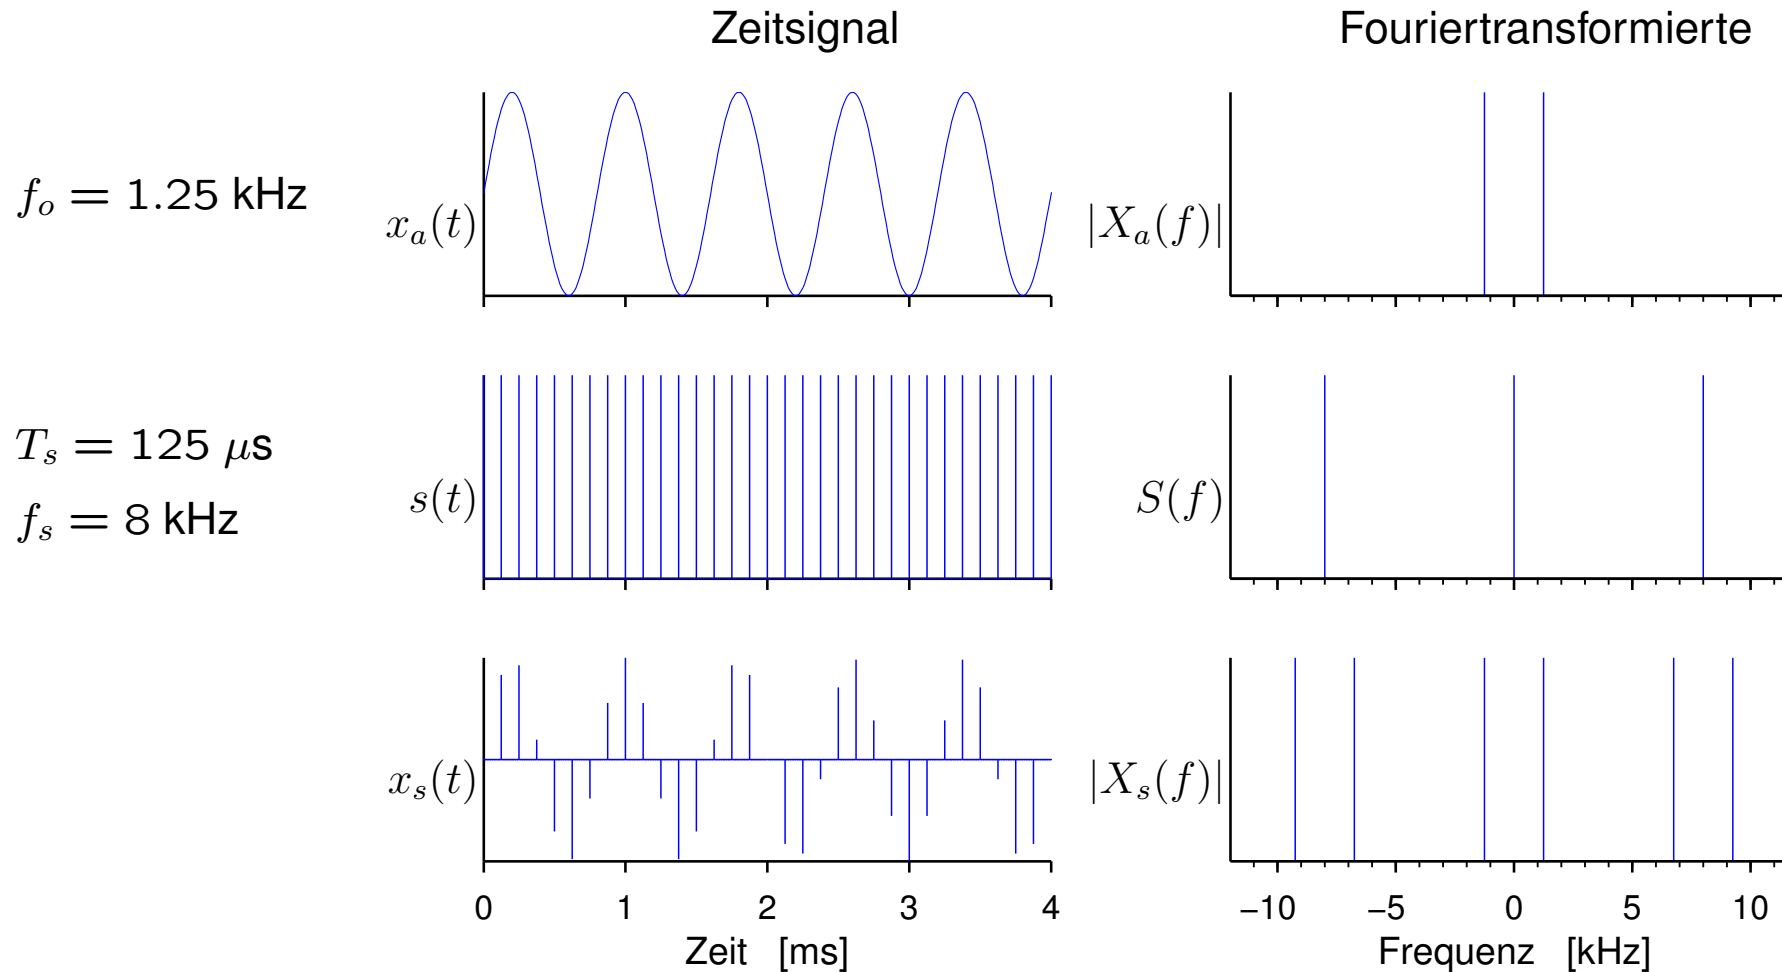
$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{j(2\pi/N)kn} \quad 0 \leq n \leq N-1$$

Zeitauflösung:  $T_s = 1/f_s$

Frequenzauflösung:  $f_s/N$

Zusammenhang zwischen DFT und kontinuierlicher FT ?


# Kontinuierliche vs. diskrete FT      Signalabtastung




# Kontinuierliche vs. diskrete FT      Analysefenster

$f_o = 1.25 \text{ kHz}$





Zeitsignal



Fouriertransformierte



Fenster: 2 ms  
( $N = 16$ )




# Kontinuierliche vs. diskrete FT




# Spektrumabtastung

$$f_o = 1.25 \text{ kHz}$$



Zeitsignal



Fouriertransformierte



$$f_s/N = 500 \text{ Hz}$$



# Diskrete Fouriertransformation

**Achtung!** Bei der Anwendung einer N-Punkt-DFT nimmt man implizit an, dass das Zeitsignal  $x(n)$  periodisch mit der Länge  $N$  ist!

**Folge:** DFT liefert nur dann die tatsächliche spektrale Zusammensetzung eines Signals, wenn der Analyseabschnitt eine ganze Anzahl Perioden des Signals enthält.

**Fragen:**

- Wie gross ist der Fehler, falls diese Bedingung nicht zutrifft?
- Was sagt die Fouriertransformierte über das Spektrum aus?



# Einfluss der Fensterfunktion auf die DFT



Form und Länge des Analysefensters beeinflussen das Resultat der DFT und damit den Analysefehler.

Multiplikation des Signals mit Fenster  $w(n)$  ergibt Faltung des Signalspektrums mit dem Spektrum  $W(k)$  des Fensters.



Zwei unerwünschte Effekte:

- Verschmieren: abhängig von Breite des Hauptlappens
- Lecken: abhängig von Höhe der Nebenlappen

# Resultat der DFT ist abhängig von Fensterfunktion



>>>



>>>



# Frequenzauflösung der Fouriertransformation

## Aufgabe:

Bestimmen der Frequenz  
eines 650 Hz Sinus  
aus  $N = 40$  Abtastwerten  
mit Abtastfrequenz  $f_s = 8$  kHz

## Problem:

Frequenzauflösung  $f_s/N = 200$  Hz !



# Verbesserung der spektralen Auflösung

Problem: Kurzer Signalabschnitt:  $x(n)$ ,  $n = 0, \dots, N-1$

Folge: Spektrale Auflösung gering, nämlich:  $f_s/N$   
(z.B. Sprachsignal mit  $f_s = 8$  kHz und  $N = 240 \rightarrow f_\Delta = 33.3$ Hz)


Lösung: Verlängerung von  $x(n)$  mit  $N$  Nullen (*zero padding*):  
ergibt die  $2N$  lange Sequenz:  $x'(n) = x_0, x_1, \dots, x_{N-1}, 0, 0, \dots, 0$   
 $\rightarrow$  spektrale Auflösung verdoppelt

Frage: Zusammenhang zwischen  $X(k)$  und  $X'(k)$  ?


Antwort:  $X(k) = X'(2k)$ , d.h. ursprüngliche Punkte unverändert, weil:

$$\begin{aligned} X'(2k) &= \sum_{n=0}^{2N-1} x'(n) e^{-j(2\pi/(2N))2kn} = \sum_{n=0}^{N-1} x(n) e^{-j(2\pi/(2N))2kn} \\ &= \sum_{n=0}^{N-1} x(n) e^{-j(2\pi/N)kn} = X(k) \end{aligned}$$


# Hochauflösende Fouriertransformation



80-Punkt-Fouriertransformation



400-Punkt-Fouriertransformation



# Spektrum rauschartiger Signale

Bisher **periodische** Signale betrachtet!

Wie ist für **rauschartige** Signale vorzugehen?  
(z.B. stimmlose Sprachsignal-Ausschnitte)

# Leistungsdichtespektrum

Schätzung des Leistungsdichtespektrum  $S(\omega)$  für die stationäre Zufallssequenz  $x(n)$  mittels DFT:


$$\tilde{S}(\omega_k) = \frac{1}{NU} |X(k)|^2 \quad \text{mit} \quad X(k) = \sum_{n=0}^{N-1} w(n)x(n)e^{-j(2\pi/N)kn}$$

$$\text{und} \quad U = \frac{1}{N} \sum_{n=0}^{N-1} w^2(n)$$



# Leistungsdichtespektrum eines Rauschsignals

Gegeben: Signal: weisses Rauschen mit 0 dB und  $f_s = 8$  kHz



Gesucht: Leistungsdichtespektrum

- Methode:
- Kurzzeit-DFT >>>
  - Kurzzeit-DFT mit Zero-Padding >>>
  - Langzeit-DFT >>>
  - Kurzzeit-DFT und Mittelung >>>

# Spektralanalyse von Sprachsignalen

Stimmhafte Abschnitte:	Kurzzeit-DFT	Frequenzauflösung durch Länge des Analysefensters gegeben (ev. mit Zero-Padding falls Genauigkeit nötig)
Stimmlose Abschnitte:	Kurzzeit-DFT	Mittelung reduziert Varianz (besser cepstrale Glättung)

# Autokorrelationsfunktion

für energiebegrenzte diskrete Signale  $x(n)$ :

$$r(k) = \sum_{m=-\infty}^{\infty} x(m) x(m+k)$$

für nicht energiebegrenzte (periodische und stationäre stochastische) diskrete Signale:

$$r(k) = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{m=-N}^N x(m) x(m+k)$$

AKF eines periodischen Signals ist auch periodisch!

# Kurzzeit-Autokorrelationsfunktion


für die Sprachverarbeitung wichtiger (endliche Summe)

$$r_n(k) = \sum_{m=n}^{n+N-1} x(m) w(m-n) x(m+k) w(m-n+k) \quad -N < k < N$$

oder äquivalent mit  $\bar{x}_n(m) = x(n+m) w(m)$

$$r_n(k) = \sum_{m=0}^{N-1-|k|} \bar{x}_n(m) \bar{x}_n(m+k) \quad |k| < N$$

**Achtung:** Mit zunehmendem  $k$  werden weniger Terme aufsummiert, weil  $\bar{x}_n(m)$  ausserhalb von  $\{0, \dots, N-1\}$  null ist!




## Effiziente Berechnung der AKF

Feststellung: AKF und Leistungsdichtespektrum bilden ein Fourierpaar

Folge: AKF kann mittels DFT berechnet werden!

Frage: Ist das Ergebnis gleich?


$\bar{x}(n)$




64 Abtastwerte




FT




$FT^{-1}$











# AKF eines stimmhaften Sprachsignalabschnittes




normierte AKF des stimmhaften Signalabschnittes




Position des 1. Maximums → Länge der Signalperiode

# AKF eines stimmlosen Sprachsignalabschnittes



normierte AKF des stimmlosen Signalabschnittes



Kein ausgeprägtes Maximum → Signal nicht periodisch

# Zusammenfassung

- Kurzzeitanalyse für quasi-stationäre Signale
- Fouriertransformation:
  - Fensterfunktion (Schmieren und Lecken)
  - hochauflösende FT (*zero padding*)
  - Spektrum nicht periodischer Signale
- Autokorrelationsfunktion:
  - Berechnung direkt oder via FT
  - Ermitteln der Signalperiode


Thema der nächsten Lektion:

Lineare Prädiktion

Zur Übersicht der Vorlesung *Sprachverarbeitung I* >>>



# Kurzzeitanalyse quasi-stationäre Signale



Verschiebung des Analysefensters:  $T_a$



Analysefrequenz oder -rate:  $F_a = 1/T_a$

<<<







## Langzeit-Spektrum stationäres Signal







# Langzeit-Spektrum Sprachsignal







## Kurzzeit-Spektrum stationäres Signal



<<<

## Kurzzeit-Spektrum stationäres Signal




<<<






# Spektrum des Sprachsignals (stimmhafter Ausschnitt)







# Spektrogramm

Schmalbandspektrogramm







## DFT mit Rechteckfensterfunktion






# DFT mit Rechteck- bzw. Hamming-Fensterfunktion




<<<









240-Punkt-DFT  
(30 ms)




<<<




240-Punkt-DFT  
(30 ms)




<<<




240-Punkt-DFT  
(30 ms)




<<<




240-Punkt-DFT  
(30 ms)



<<<




240-Punkt-DFT  
(30 ms)




<<<







30 ms-Fenster  
(240 Abtastwerte)  
2048-Punkt-DFT



<<<




30 ms-Fenster  
(240 Abtastwerte)  
2048-Punkt-DFT




<<<






30 ms-Fenster  
(240 Abtastwerte)  
2048-Punkt-DFT




<<<





800-Punkt-DFT  
(100 ms)




<<<



# Leistungsdichtespektrum eines Rauschsignals:

Mittelung über 10 Analysefenster (240-Punkt-DFT)



<<<

